

9/3/2017

Στατιστικός


Τυχείο Δείγμα

(Αντισπροσωπικό υποσύνολο των πληθυσμών)

Έστω n (μέγεθος του δείγματος) μέλη του πληθυσμού απαρτίζουν το τυχείο δείγμα (τ.δ.)

Μετρώ το χαρακτηριστικό X στα n μέλη του δείγματος (τ.δ.).

Πρακτικά έτσι το τ.δ. x_1, x_2, \dots, x_n




Πληθυσμός

Είναι η περισσότερη χαρακτηριστικά χαρακτηριστικά των μελών του πληθυσμού.

Τυχία $n \cdot x$ μεταβλητό X

Γνωρίζω ότι f η κατανομή της X



Εάν $X \sim N(\mu, \sigma^2)$ αν γνωρίζω την άγνωστη παράμετρο μ ή σ^2 $N(\mu, \sigma^2)$ $\pi \cdot x = f_x$ (πυκνότητα) \uparrow Παραμετρικός στατιστικός

αν δεν γνωρίζω τα παραμετρικά έγκυρα $n \cdot x$

Μη παραμετρικός στατιστικός

(αν το δείγμα είναι αντιπροσωπικό!!!)

Πρόβλημα: Η πρόβλεψη ή η εκτίμηση των άγνωστων παραμέτρων της κατανομής

Στατιστική Συμπερασματική:

Μέθοδος στατιστικής που αναπτύσσει μεθόδους για την πρόβλεψη (εκτίμηση) των άγνωστων παραμέτρων της κατανομής που περιγράφει την τ.φ. X

I Εκτίμηση σε σημείο

II Εκτίμηση σε διάστημα (Διαστήματα εμπιστοσύνης)

III Έλεγχος Στατιστικών Υποθέσεων (Στατιστικά τεστ)

Εκτίμηση σε σημείο

Στατιστική - Ορολογία

- Έστω τυχαίο δείγμα (τ.δ.) μεγέθους n από πληθυσμό με κατανομή $f(x, \theta)$, n οποία εξαρτάται από μια παράμετρο $\theta \in \Theta \subseteq \mathbb{R}$ (ή \mathbb{R}^m)

Ειδικότερα το τ.δ. x_1, \dots, x_n υποκείμε:

σε δύο αναζητήσεις:

- Θ , x_1, \dots, x_n είναι τ.λ. ανεξαρτήτων
- Θ , x_1, \dots, x_n είναι ισονοητα, δηλ. περιγράφονται από την ίδια κατανομή $f(x, \theta)$

Το σύνολο $\Theta \leftarrow$ Παράμετρικός χώρος
και είναι συνήθως $\subseteq \mathbb{R}$


π.χ. Έστω τ.δ. x_1, \dots, x_n από πληθυσμό με $\text{Exp}(\theta)$

$$f(x, \theta) = \theta e^{-\theta x} \quad x > 0, \theta > 0$$

$$\text{Άρα } \Theta = \{\theta \in \mathbb{R} : \theta > 0\} = (0, \infty) \quad \text{--- } \Theta$$

Έστω τ.δ. x_1, \dots, x_n από πληθυσμό $N(\mu, \sigma^2)$, $f(x, \theta) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$
 $-\infty < \mu < \infty, \sigma^2 > 0$

$$\Theta = \left\{ \theta = (\mu, \sigma^2) : \begin{array}{l} \mu \in \mathbb{R} \\ \sigma^2 > 0 \end{array} \right\}$$



Στατιστική Συναρτηση

Έστω τ.δ. x_1, \dots, x_n από πληθυσμό
με κατανομή $f(x, \theta)$, $\theta \in \Theta$

Στατιστική Συναρτηση: Κάθε συνάρτηση του τ.δ. x_1, \dots, x_n και $T = T(x_1, \dots, x_n)$

π.χ. στατιστικών συναρτήσεων $T = \bar{x} = \frac{1}{n} \sum x_i$

$$T = S^2 = \frac{1}{n-1} \sum (x_i - \bar{x})^2$$

Εκτίμηση: Τη στατιστική συνάρτηση του κριτηρίου για την εκτίμηση (προσέγγιση) της άγνωστης παραμέτρου θ ή μιας συνάρτησης $g(\theta)$ της θ .

Κριτήρια Επιλογής Εκτιμητών - Μέσο τετραγωνικό σφάλμα

Έστω ένας εκτιμητής $T = T(x_1, \dots, x_n)$ της $g(\theta)$, $\theta \in \Theta$.
 Ο T θα είναι καλός εκτιμητής της $g(\theta)$ αν $|T - g(\theta)|$ είναι μικρός

Αδυναμίες $|T - g(\theta)|$

(i) Η απόδοση της είναι διαφορετική

(ii) Η $|T - g(\theta)|$ εξαρτάται από το τ.δ. x_1, \dots, x_n

Για να αρθούν οι αδυναμίες (i) και (ii)

ο T θα είναι καλός εκτιμητής αν η τιμή της $E[T - g(\theta)]^2$ είναι μικρή

Ορισμός: (Μέσο τετραγωνικό σφάλμα)

Έστω $T = T(x_1, \dots, x_n)$ εκτιμητής της $g(\theta)$

Το μέσο τετραγωνικό σφάλμα του εκτιμητή T για την εκτίμηση της $g(\theta)$ ορίζεται:

$$MSE(T, \theta) = E(T(x_1, \dots, x_n) - g(\theta))^2 = E(T - g(\theta))^2$$

Πρόταση: $MSE(T, g(\theta)) = \text{Var}(T) + (E(T) - g(\theta))^2$

Απόδειξη: $\text{Var}(W) = E(W^2) - (E(W))^2$

$$MSE(T, g(\theta)) = E(T - g(\theta))^2$$

$$= \text{Var}(T - g(\theta)) + (E(T - g(\theta)))^2$$

$$= \text{Var}(T) + (E(T) - g(\theta))^2$$

$\text{Var}g(\theta) = 0$
 αφού $g(\theta)$ σταθερά
 $\text{Var}(T - g(\theta)) = \text{Var}T + \text{Var}g(\theta)$

Έστω τ.σ. x_1, \dots, x_n από παράγωγο τ.ε κατανομή $Ex \sim (1/\theta)$, $\theta > 0$.
 Έστω ο εκτιμητής \bar{x}
 Να βρεθεί ΜΤΣ (\bar{x}, θ)

Από πρόταση ΜΤΣ $(\bar{x}, \theta) = \text{Var}(\bar{x}) + (E(\bar{x}) - \theta)^2$
 $E(\bar{x}) = E\left(\frac{1}{n} \sum x_i\right) = \frac{1}{n} \sum E(x_i) = \frac{1}{n} \sum \theta = \theta$

$\text{Var}(\bar{x}) = \text{Var}\left(\frac{1}{n} \sum x_i\right) = \frac{1}{n^2} \text{Var}\left(\sum x_i\right)$

$\text{Var}\left(\sum_{i=1}^n a_i w_i\right) = \sum_{i=1}^n a_i^2 \text{Var}(w_i) + \sum_{i=1}^n \sum_{j=1, j \neq i}^n a_i a_j \text{Cov}(w_i, w_j)$

Αν w_i ανεξάρ. τότε $\text{Cov}(w_i, w_j) = 0$ και έτσι $\text{Var}\left(\sum_{i=1}^n a_i w_i\right) = \sum_{i=1}^n a_i^2 \text{Var}(w_i)$

$\xrightarrow{\text{ανεξάρ.}} \text{Var}(\bar{x}) = \frac{1}{n^2} \sum_{i=1}^n \text{Var}(x_i) = \frac{1}{n^2} \sum_{i=1}^n \frac{1}{(1/\theta)^2} = \frac{1}{n^2} \sum_{i=1}^n \theta^2$

$\Rightarrow \text{Var}(\bar{x}) = \frac{\theta^2}{n}$

Άρα $\boxed{\text{ΜΤΣ}(\bar{x}, \theta) = \frac{\theta^2}{n} + \theta^2 = \frac{\theta^2}{n}}$

Παράδειγμα: Αν $n \rightarrow \infty$ τότε $\text{ΜΤΣ}(\bar{x}, \theta) \rightarrow 0$

Ορισμός: Έστω οι εκτιμητές T_1 και T_2 για την εκτίμηση της $g(\theta)$
 Ο T_1 θα λέγεται καλύτερος από τον T_2 με κριτήριο το ΜΤΣ αν:

(α) $\text{ΜΤΣ}(T_1, \theta) \leq \text{ΜΤΣ}(T_2, \theta), \forall \theta \in \Theta$

(β) $\text{ΜΤΣ}(T_1, \theta_0) < \text{ΜΤΣ}(T_2, \theta_0)$, για κάποιο $\theta_0 \in \Theta$ (παρατηρητικός χώρος)

Παρατήρηση: (α) Ο T_2 θα λέγεται n -αποδοκτός

(β) Ένας εκτιμητής λέγεται αποδοκτός αν δεν υπάρχει καλύτερος από αυτόν.


Καλύτερος εκτιμητής είναι εκείνος που έχει το μικρότερο ΜΤΣ

Αλλά αποδείξτε ότι

$$ΜΤΣ(T, \theta) = \text{Var}(T) + (E(T) - g(\theta))^2$$

→ Καλύτερος εκτιμητής είναι εκείνος που (i) έχει το μικρότερο διακύβευμα ($\text{Var}(T)$)
(ii) το μικρότερο ($E(T) - g(\theta)$)².

Γιναι λογικά τα (i) και (ii):



Ορισμός (Ανεξαρτησία)

Ο εκτιμητής $T = T(x_1, \dots, x_n)$ λέγεται ανεξάρτητος της $g(\theta)$ αν $E(T) = g(\theta)$.

Ορισμός (Μερόσημος)

Η μερόσημος του εκτιμητή T της $g(\theta)$ ορίζεται με $b(T, \theta)$ και είναι $b(T, \theta) = E(T) - g(\theta)$.

Πρόταση: (a) $ΜΤΣ(T, \theta) = \text{Var}(T) - b^2(T, \theta)$

(b) Αν ο T ανεξάρτητος της $g(\theta)$ τότε $b(T, \theta) = 0$

(c) Αν ο T ανεξάρτητος της $g(\theta)$ τότε $ΜΤΣ(T, \theta) = \text{Var}(T)$

Το (a) παρακίει για τον ορισμό ΑΟΕΔ εκτιμητή

Ορισμός Ο εκτιμητής T της $g(\theta)$ λέγεται ανεξάρτητος οπούοποια ελάχιστη διακύβευσης (ΑΟΕΔ) αν ο T είναι ανεξάρτητος της $g(\theta)$ και έχει το μικρότερο διακύβευμα από όλους τους άλλους ανεξάρτητους εκτιμητές της $g(\theta)$.

Παράδειγμα 1 Έστω τ.δ. x_1, \dots, x_n από τ.δ. με μέση τιμή μ και διακύμανση σ^2

NΔO (i) ο \bar{x} αξιοπρόσθετος τ.δ. μ
 (ii) $\text{Var}(\bar{x}) = \frac{\sigma^2}{n}$

(i) Αρκεί να δείξω $E(\bar{x}) = \mu$ (από τον ορισμό)

$$E(\bar{x}) = E\left(\frac{1}{n} \sum x_i\right) = \frac{1}{n} \sum E(x_i) = \frac{1}{n} \sum \mu = \frac{1}{n} n\mu = \mu \quad \text{Για όλα τις κατανομές ισχύει.}$$

$$(ii) \text{Var}(\bar{x}) = \text{Var}\left(\frac{1}{n} \sum x_i\right) = \frac{1}{n^2} \text{Var}\left(\sum x_i\right) \stackrel{x_1, \dots, x_n \text{ ανεξ.}}{=} \frac{1}{n^2} \sum_{i=1}^n \text{Var}(x_i) = \frac{1}{n^2} \sum_{i=1}^n \sigma^2 = \frac{1}{n^2} n\sigma^2 = \frac{\sigma^2}{n}$$

Άρα ο \bar{x} είναι αξιοπρόσθετος του τ.δ. x_i .

Παράδειγμα 2

Έστω τ.δ. x_1, \dots, x_n από τ.δ. με μέση τιμή μ και διακύμανση σ^2
 NΔO η δείγματική διακύμανση

$S^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$ είναι αξιοπρόσθετος εκτιμητής σ^2

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i^2 - 2x_i\bar{x} + \bar{x}^2) = \frac{1}{n-1} \left\{ \sum x_i^2 - 2\bar{x} \sum x_i + n\bar{x}^2 \right\} =$$

$$= \frac{1}{n-1} \left(\sum x_i^2 - 2n\bar{x}^2 + n\bar{x}^2 \right) \Rightarrow S^2 = \frac{1}{n-1} \left(\sum x_i^2 - n\bar{x}^2 \right)$$

$$E(S^2) = E\left\{ \frac{1}{n-1} \left(\sum x_i^2 - n\bar{x}^2 \right) \right\} = \frac{1}{n-1} \left\{ \sum E(x_i^2) - nE(\bar{x}^2) \right\} =$$

$$\text{Var}(W) = E(W^2) - (E(W))^2 = \frac{1}{n-1} \left\{ \sum (\text{Var}(x_i) + (E x_i)^2) - n(\text{Var}(\bar{x}) + (E \bar{x})^2) \right\} =$$

$$= \frac{1}{n-1} \left\{ \sum (\sigma^2 + \mu^2) - n\left(\frac{\sigma^2}{n} + \mu^2\right) \right\} = \frac{1}{n-1} \left\{ n\sigma^2 + n\mu^2 - \sigma^2 - n\mu^2 \right\} = \frac{(n-1)\sigma^2}{n-1} = \sigma^2$$